

BAB II

LANDASAN TEORI

A. Suhu Udara

1. Definisi Suhu Udara

Suhu adalah ukuran derajat panas atau dinginnya suatu benda, semakin tinggi suhu suatu benda maka semakin panas pula benda tersebut, begitu juga sebaliknya (Supu et al., 2016). Alat yang digunakan untuk mengukur suhu disebut termometer. Satuan suhu diantaranya Kelvin (K), Celcius (C), Fahrenheit (F), dan Reamur (R). Suhu udara akan berfluktuasi setiap 24 jam, fluktuasi suhu udara berkaitan dengan proses pertukaran energi yang berlangsung di atmosfer. Di siang hari, setengah dari radiasi matahari akan diserap oleh gas-gas di atmosfer dan partikel-partikel padat yang melayang di atmosfer. Serapan energi radiasi akan menyebabkan suhu udara meningkat. Suhu udara maksimum tercapai setelah intensitas cahaya maksimum tercapai. Intensitas cahaya maksimum tercapai pada saat berkas cahaya jatuh tegak lurus, yakni pada waktu tengah hari (Lakitan, 2002).

Suhu maksimum tertinggi umumnya tercapai pada sekitar bulan Oktober (pada akhir musim kemarau), sedangkan suhu minimum terendah tercapai sekitar bulan Juli dan Agustus. Suhu maksimum rata – rata di Indonesia umumnya tidak melebihi 32°C (Putri, 2013).

2. Pengukuran Suhu Pada Stasiun Meteorologi

Suhu udara yang dilaporkan adalah suhu suhu udara yang diukur dengan menggunakan termometer yang diletakan dalam sangkar meteorologi berwarna putih pada ketinggian 1,2 – 1,5 meter dari permukaan tanah (Putri, 2013). Suhu harian rata-rata dihitung berdasarkan rata-rata suhu pada beberapa kali pengamatan dalam setiap periode 24 jam (sehari semalam), sedangkan suhu udara

maksimum dan minimum diukur menggunakan termometer maksimum dan minimum yang dihitung berdasarkan satu kali pengamatan dalam setiap periode 24 jam (sehari semalam).

B. Peramalan

Peramalan merupakan suatu teknik untuk memperkirakan suatu nilai pada masa yang akan datang dengan memperhatikan data masa lalu maupun data saat ini (Aswi & Sukarna, 2006). Peramalan dikategorikan menjadi dua bagian utama, yakni

1. Kualitatif

Peramalan kualitatif kebanyakan digunakan pada peramalan logis, pemikiran intuitif dan informasi atau pengetahuan yang di peroleh dari peneliti sebelumnya. Metode peramalan kualitatif ini sifatnya lebih subjektif dibandingkan dengan kuantitatif. Hal ini karena metode peramalan kualitatif dipengaruhi oleh emosi, pendidikan, intuisi, atau pengalaman si peramal sehingga hasil setiap orang kemungkinan akan berbeda.

2. Kuantitatif

Peramalan kuantitatif yaitu prakiraan dengan menggunakan metode statistik dan matematik, peramalan kuantitatif merupakan metode peramalan yang mendasarkan prakiraan atau peramalannya menggunakan data yang lalu, dengan menggunakan *predictor* untuk masa mendatang (Assauri, 2008). Jadi dapat disimpulkan dengan mengolah data aktual produk yang lalu, maka dapat ditemukan suatu hasil prakiraan atau peramalan dengan menggunakan metode peramalan kuantitatif. Peramalan kuantitatif menggunakan bermacam-macam model matematika yang bergantung pada data historis dan atau variabel asosiatif (Heizer & Render, 2015). Peramalan kuantitatif hanya dapat digunakan apabila terdapat kondisi sebagai berikut:

- a. Tersedianya informasi tentang masa lalu.
- b. Adanya informasi yang dapat dikuantifikasikan dalam bentuk data numerik.

- c. Dapat diasumsikan bahwa pola yang lalu akan berkelanjutan pada masa yang akan datang.

Hasil peramalan yang dibuat sangat bergantung pada metode yang digunakan serta perbedaan atau penyimpangan antara hasil ramalan yang didapat dengan kenyataan yang terjadi. Terdapat dua jenis metode peramalan kuantitatif yaitu metode deret waktu (*time series*) dan metode asosiatif (*causal*).

C. Deret Waktu (*Time Series*)

Data deret waktu merupakan data yang dikumpulkan, dicatat atau diobservasi sepanjang waktu secara berurutan. Periode waktu observasi dapat berbentuk tahun, kuartal, bulan, minggu dan di beberapa kasus dapat juga hari atau jam. Metode deret waktu adalah metode yang menganalisis serangkaian data dan menemukan pola variasi masa lalu yang dapat digunakan untuk memperkirakan nilai masa depan.

Contoh dari metode ini antara lain metode *naïve*, metode pergerakan rata-rata (*moving average*) dan metode penghalusan eksponensial (*exponential smoothing*). Dengan mempertimbangkan jenis pola data yang terbentuk maka dapat diketahui metode peramalan yang paling tepat dan cocok untuk digunakan. Terdapat empat jenis pola yang dapat dibedakan menurut (Makridakis et al., 1998), yaitu sebagai berikut:

1. Pola *Trend(T)*

Pola data *trend* terjadi ketika data pengamatan mengalami kenaikan atau penurunan selama periode jangka panjang. Suatu data pengamatan yang mempunyai *trend* disebut data nonstasioner.

2. Pola Musiman (*Seasonal*)

Pola data musiman terjadi ketika suatu data deret waktu dipengaruhi oleh faktor musim yang berulang dari periode ke periode berikutnya. Misalnya pola yang berulang setiap hari tertentu, minggu tertentu, bulan tertentu, tahun tertentu atau pada kuartalan tertentu.


3. Pola Stationer

Pola data stasioner yang terjadi apabila nilai data berfluktuasi di sekitar nilai rata-rata yang tetap.

4. Pola Siklus (*Cyclical*)

Pola data yang terjadi apabila data menunjukkan kenaikan dan penurunan tidak pada periode yang tetap / acak.

Berikut ini adalah contoh pola data diatas :



Gambar 1. Contoh Pola Data

D. Proses *White Noise*

Proses *White Noise* adalah salah satu bentuk proses menstasionerkan data. Proses *White Noise* yang dinotasikan $\{e_t\}$ adalah suatu proses yang independen dan berdistribusi tertentu dengan *mean* konstan (biasanya diasumsikan 0), dan variansi konstan σ_a^2 (Sukmawaty, 2019).

Proses *white noise* $\{e_t\}$ dengan autokovarians :

$$\gamma_k = \begin{cases} \sigma_a^2, & k = 0 \\ 0, & k \neq 0 \end{cases} ,$$

dengan fungsi autokorelasi :

$$\rho_k = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases} ,$$

serta fungsi autokorelasi parsial :


$$\phi_{kk} = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases} ,$$

dengan demikian proses *White Noise* bersifat stasioner. Proses ini merupakan “*building-block*” bagi proses stasioner lainnya.


E. ARIMA

Metode *Autoregressive Integrated Moving Average* (ARIMA) atau sering disebut juga Metode Box-Jenkins, dikenalkan dan dikembangkan oleh G. E. P. Box dan G. M. Jenkins pada tahun 1960-an. Metode ARIMA merupakan metode yang mengabaikan variabel independen dalam membuat peramalan. Metode ARIMA cocok digunakan jika data yang dianalisis merupakan data deret waktu yang saling berhubungan satu sama lain (*autoregressive*). Dalam pemodelan ARIMA biasanya dinotasikan sebagai $ARIMA(p,d,q)$ dengan p merupakan orde dari *autoregressive* dan q merupakan orde dari rata-rata bergerak, sedangkan untuk d adalah banyak proses pembeda yang dilakukan untuk memperoleh data yang stasioner (Rosadi, 2014).

Orde *autoregressive* dapat ditentukan berdasarkan *cut-off* yang terdapat pada grafik *partial autocorrelation function* (PACF) dan orde rata-rata bergerak dapat ditentukan berdasarkan *cut-off* yang terdapat pada grafik *autocorrelation function* (ACF). Berikut contoh tampilan grafik ACF dan PACF :



Gambar 2. Tampilan ACF



Gambar 3. Tampilan PACF

Berikut ini adalah proses dari pemodelan ARIMA ;

1. Proses *Autoregressive* (AR)

Model $AR(p)$ adalah model dimana X_t merupakan fungsi dari data dimasa lalu, yakni $t-1, t-2, \dots, t-p$. Bentuk umum dari proses *autoregresif* tingkat p atau $AR(p)$ adalah :

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t \quad , \quad (1.1)$$

dengan :

ϕ_i : koefisien regresi ($i = 1, 2, \dots, p$)

X_t : nilai pengamatan / *variable* pada waktu ke- t

e_t : nilai *error* pada waktu ke- t

Dalam hal ini diasumsikan e_t adalah independen dengan X_{t-1}, X_{t-2}, \dots . Persamaan tersebut biasanya juga ditulis dalam bentuk :

$$\phi(B)X_t = e_t \quad , \quad (1.2)$$

dengan

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad , \quad (1.3)$$

keterangan :

e_t : nilai *error* pada waktu ke- t

p : orde AR

B : Backward shift

Untuk contoh salah satu model *autoregressive* tingkat 1 atau proses AR(1), dapat didefinisikan sebagai berikut :

$$X_t = \phi_1 X_{t-1} + e_t \text{ dimana } e_t \sim N(0, \sigma_a^2) \quad , \quad (1.4)$$

asumsikan e_t independen terhadap X_{t-1} , lalu ambil varians pada kedua sisi dari persamaan (1.4) diperoleh :

$$\text{var}(X_t) = \phi_1^2 \text{var}(X_{t-1}) + \text{var}(e_t) \quad , \quad (1.5)$$

$$Y_0 = \phi_1^2 Y_0 + \sigma_a^2 \quad (1.6)$$

penyelesaian untuk Y_0 menghasilkan :

$$Y_0 = \frac{\sigma_a^2}{1-\phi_1^2} \quad , \quad (1.7)$$

dimana ($-1 < \phi_1 < 1$ atau $|\phi_1| < 1$) , dalam hal ini agar ($\text{var}(X_t) = Y_0$) ernilai berhingga dan tidak negatif.

dengan cara mengalikan persamaan (1.4) dengan X_{t-k} dan mengambil ekspektasinya, diperoleh fungsi autokovarians

$$E[X_t X_{t-k}] = E[\phi_1 X_{t-1} X_{t-k}] + E[e_t X_{t-k}] \quad , \quad (1.8)$$

atau

$$Y_k = \phi_1 Y_{k-1} + E[e_t X_{t-k}] \quad , k \geq 1 \quad , \quad (1.9)$$

sehingga fungsi autokorelasi (ACF) untuk proses AR(1) menjadi :

$$\rho_k = \phi_1 \rho_{k-1} = \phi_1^k \quad , \quad |\phi_1| < 1 \quad , \quad (1.10)$$

dengan demikian, ketika $|\phi_1| < 1$ dan proses adalah stasioner maka nilai-nilai ACF akan turun eksponensial mengikuti satu

diantara dua bentuk pola yang tergantung dari tanda ϕ_1 . Jika $0 < \phi_1 < 1$ maka semua autokorelasinya adalah positif, dan jika $-1 < \phi_1 < 0$ maka tanda autokorelasi menunjukkan perubahan pola yang dimulai dengan suatu nilai yang negatif.

2. Proses *Moving Average* (MA)

Model MA(q) adalah model untuk memprediksi X_t sebagai fungsi dari kesalahan prediksi di masa lalu (*past prediction error*) dalam memprediksi X_t . Bentuk umum dari proses *moving average* tingkat q atau MA(q) adalah:

$$X_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad , \quad (1.11)$$

keterangan :

X_t : nilai pengamatan / *variable* pada waktu ke- t

θ_i : koefisien regresi ($i = 1, 2, \dots, q$)

e_t : nilai *error* pada waktu ke- t

q : orde MA

dimana e_t adalah independen dan berdistribusi normal dengan mean 0 dan varians σ_a^2 . persamaan (1.11) ini juga dapat ditulis dalam bentuk :

$$X_t = \theta(B)e_t \quad , \quad (1.12)$$

dengan

B : *Backward shift*

dengan $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ yang dikenal dengan operator MA(q). *Mean* dan *varians* dari model MA(q) ini selanjutnya dapat dihitung :

$$E(X_t) = E(e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}) = 0, \quad (1.13)$$

dan

$$(va(X_t) = var(e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}), \quad (1.14)$$

$$\gamma_0 = (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2)\sigma_a^2, \quad (1.15)$$

untuk q berhingga, maka proses MA ini akan selalu stasioner. Persamaan (1.12) dapat juga ditulis :

$$\theta^{-1}(B)X_t = e_t, \quad (1.16)$$

atau

$$X_t - \pi_1 X_{t-1} - \pi_2 X_{t-2} - \dots = e_t, \quad (1.17)$$

atau

$$\pi(B)X_t = e_t. \quad (1.18)$$

Proses MA(q) dikatakan *invertible*, dapat ditulis dalam bentuk AR tingkat tak berhingga, jika harga koefisien-koefisien π merupakan deret yang konvergen, yaitu apabila akar-akar $\pi(B) = 0$ semuanya terletak diluar lingkaran satuan, suatu syarat yang serupa dengan syarat stasioneritas dari suatu proses AR(p). Persamaan (1.18) menunjukkan bahwa proses MA(q) ekuivalen dengan suatu proses AR(p) , $\phi(B)X_t = e_t$ dengan $\phi(B) = \pi(B) = \theta^{-1}(B)$, yaitu proses AR(∞). Dengan cara yang sama, suatu proses AR(p), $\phi(B)X_t = e_t$ (yang selalu *invertible*) dapat ditulis sebagai suatu proses MA(∞), $X_t = \psi(B)e_t$, dimana $\psi(B) = \phi^{-1}(B)$

Untuk contoh salah satu Model *Moving Average* tingkat 1 atau proses MA(1) didefinisikan sebagai berikut :

$$X_t = e_t - \theta_1 e_{t-1}, \text{ dimana } (-1 < \theta_1 < 1). \quad (1.19)$$

Kemudian mengalikan persamaan (1.19) dengan X_{t-k} , jelasnya $E(X_t) = 0$, maka diperoleh :

$$E(X_t X_{t-k}) = E[(e_t - \theta_1 e_{t-1})(e_{t-k} - \theta_1 e_{t-1-k})], \quad (1.20)$$

dalam hal ini diperoleh $E(X_t X_{t-k}) = 0$ untuk $k \geq 2$, yang berarti proses tidak mempunyai korelasi diluar lag 1.

Sebagai ringkasan proses MA(1) sebagai berikut :

$$E(X_t) = 0, \quad (1.21)$$

$$\gamma_0 = \text{var}(X_t) = \sigma_e^2(1 + \theta_1^2), \quad (1.22)$$

$$\gamma_1 = -\theta_1 \sigma_e^2, \quad (1.23)$$

$$\rho_1 = \frac{-\theta_1}{1 + \theta_1^2}, \quad (1.24)$$

dan

$$\gamma_k = \rho_k = 0 \text{ untuk } k \geq 2$$

3. Proses *Autoregressive - Moving Average*

Suatu proses yang diperoleh dari model AR dan MA adalah model campuran yang berbentuk :

$$X_t = \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q}, \quad (1.25)$$

yang dinamakan model ARMA (p, q) , biasanya ditulis :

$$\phi(B)X_t = \theta(B)e_t, \quad (1.26)$$

keterangan :

p : orde dari AR

q : orde dari MA

ϕ_p : koefisien orde p

θ_q : koefisien orde q

B : *backward shift*

e_t : nilai *error* pada waktu ke- t

Syarat-syarat stasioneritas dan invertibilitas memerlukan akar-akar dari $\phi(B) = 0$ dan $\theta(B) = 0$ terletak diluar lingkaran satuan. Dengan mengambil ekspektasi persamaan (1.25) diperoleh $E(X_t) = 0$.

Secara umum model ARMA(p, q) dapat ditulis dalam bentuk MA(∞) atau AR(∞), yaitu :

$$X_t = \psi(B)e_t, \quad (1.27)$$

atau

$$\pi(B)X_t = e_t, \quad (1.28)$$

dimana

$$\psi(B) = \phi^{-1}(B) \theta(B), \quad (1.29)$$

dan

$$\pi(B) = \phi(B) \theta^{-1}(B), \quad (1.30)$$

adalah deret tak berhingga dalam B . Sehingga dengan menyatakan model itu dalam bentuk AR dan MA akan mendapat pola ACF dan PACF yang berkurang terus menerus.

4. Proses *Autoregressive Integrated Moving Average*

Model ARIMA dilakukan pada data stasioner atau data yang dipembeda sehingga data telah stasioner. Secara umum, model ARIMA dinotasikan sebagai ARIMA (p, d, q). Model ini merupakan gabungan dari model ARMA (p, q) dan proses pembeda (*differencing*), yaitu :

$$(1 - \phi_1 B - \dots - \phi_p B^p)(1 - B)^d X_t = (1 - \theta_1 B - \dots - \theta_q B^q) e_t, \quad (1.31)$$

keterangan :

p	: orde dari AR
q	: orde dari MA
ϕ_p	: koefisien orde p
θ_q	: koefisien orde q
B	: <i>backward shift</i>
$(1 - B)^d$: orde <i>differencing</i> non musiman
d	: banyaknya <i>differencing</i> yang dilakukan untuk menstasionerkan data.
e_t	: Nilai <i>error</i> pada waktu ke- t

F. EXPONENTIAL SMOOTHING

1. Metode Penghalusan Eksponensial Orde Satu (*Single Exponential Smoothing*)

Metode penghalusan eksponensial orde satu (*single exponential smoothing*) hanya digunakan untuk data tanpa komponen *trend* dan musiman dan digunakan hanya untuk peramalan satu satuan waktu ke depan $t+1$. Model dari *Single Exponential Smoothing* :

$$S_t = \alpha X_t + (1 - \alpha) S_{t-1}, \text{ dengan } (0 < \alpha < 1), \quad (2.1)$$

keterangan :

S_t : nilai pemulusan awal

X_t : data *series* waktu ke t

α : parameter nilai level

S_{t-1} : nilai pemulusan awal ke $t-1$

2. Metode Penghalusan Eksponensial Orde Dua (*Double Exponential Smoothing*)

Metode ini digunakan saat terdapat *trend* dalam data, yang terdiri dari dua parameter yaitu α sebagai parameter dalam penghalusan “level” atau rata-rata dari data, dan parameter kedua yaitu β , merupakan parameter untuk penghalusan *trend* (Rosadi,

2016). Persamaan yang dipakai dalam *Double Exponential Smoothing* adalah sebagai berikut:

$$S_t = \alpha X_t + (1 - \alpha) (S_{t-1} + T_{t-1}), \text{ dengan } (0 < \alpha < 1), \quad (2.2)$$

dengan nilai *trend*

$$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}, \text{ dengan } (0 < \beta < 1), \quad (2.3)$$

ramalan untuk m periode kedepan

$$F_{t+m} = S_t + mT_t, \quad (2.4)$$

keterangan :

S_t : nilai pemulusan awal

X_t : data *series* waktu ke t

T_t : konstanta pemulusan

α : parameter nilai level

β : parameter nilai *trend*

T_{t-1} : nilai *trend* waktu ke $t-1$

F_{t+m} : ramalan untuk m periode ke depan dari t .

3. Metode Penghalusan Eksponensial Orde Tiga (*Exponential Smoothing Holt-Winters*)

Metode Holt-Winters sering disebut metode pemulusan eksponensial yang melakukan pendekatan (Triangga, 2020). Metode ini terbagi menjadi dua bagian yakni:

- a. Metode Pemulusan *Exponential Holt-Winters* dengan Metode Perkalian Musiman (*Multiplicative Seasonal Method*) yang digunakan untuk variasi data musiman yang mengalami peningkatan/penurunan (fluktuasi).
- b. Metode Pemulusan *Exponential Holt-Winters* dengan Metode Penambahan Musiman (*Additive Seasonal Method*) yang digunakan untuk variasi musiman yang bersifat konstan.

Metode *Holt-Winters* didasarkan pada tiga persamaan pemulusan, yakni persamaan pemulusan level, pemulusan *trend*, dan persamaan pemulusan musiman (Hamidah et al., 2017). Untuk Pemulusan

Exponential Holt-Winters dengan Metode Perkalian Musiman mempunyai persamaan sebagai berikut :

Pemulusan level

$$S_t = \alpha \frac{X_t}{I_{t-L}} + (1 - \alpha)(S_{t-1} + T_{t-1}), \quad (2.5)$$

pemulusan *trend*

$$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}, \quad (2.6)$$

pemulusan musiman

$$I_t = \gamma \frac{X_t}{S_t} + (1 - \gamma)I_{t-L}, \quad (2.7)$$

ramalan untuk m periode kedepan

$$F_{t+m} = (S_t + T_t m)I_{t-L+m}, \quad (2.8)$$

Untuk Pemulusan *Exponential Holt-Winters* dengan Metode Penambahan Musiman mempunyai persamaan sebagai berikut:

pemulusan level

$$S_t = \alpha(X_t - I_{t-L}) + (1 - \alpha)(S_{t-1} + T_{t-1}), \quad (2.9)$$

pemulusan *trend*

$$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}, \quad (2.10)$$

pemulusan musiman

$$I_t = \gamma(X_t - S_t) + (1 - \gamma)I_{t-L}, \quad (2.11)$$

ramalan untuk m periode kedepan

$$F_{t+m} = S_t + T_t m + I_{t-L+m}, \quad (2.12)$$

keterangan:

X_t : nilai aktual pada periode akhir t

α : konstanta penghalusan untuk data ($0 < \alpha < 1$)

β : konstanta penghalusan untuk *trend* ($0 < \beta < 1$)

γ : konstanta penghalusan untuk musiman ($0 < \gamma < 1$)

S_t : nilai pemulusan awal

T_t : konstanta pemulusan

T : komponen *trend*

I : faktor penyesuaian musiman

L : panjang musim/ periode

F_{t+m} : ramalan untuk m periode ke depan dari t .

Dalam pemulusan eksponensial, nilai awal sangat dibutuhkan, karena peramalan untuk $t - 1$ belum tersedia. Artinya nilai ramalan S_{t-1} belum ada.

Menurut metode pemulusan eksponensial dari *Holt-Winters* dapat digunakan dengan mengambil secara sembarang beberapa nilai awal yang telah ditetapkan yakni:

$$S_{L-1} = X_{L-1}, \quad (2.13)$$

nilai awal lain yang dapat digunakan adalah:

$$S_L = \frac{1}{L} (X_1 + X_2 + \dots + X_L), \quad (2.14)$$

$$T_L = \frac{1}{K} \left(\frac{(X_{L+1} - X_1)}{L} + \frac{(X_{L+2} - X_2)}{L} + \dots + \frac{(X_{L+k} - X_k)}{L} \right), \quad (2.15)$$

$$I_k = \frac{X_k}{S_L}, \quad (2.16)$$

dimana $k = 1, 2, 3, \dots, L$

G. Kendala dalam Peramalan

Ketepatan dari suatu metode peramalan merupakan kesesuaian dari suatu metode yang menunjukkan seberapa jauh model peramalan tersebut mampu meramalkan data aktual. Nilai dari hasil peramalan mungkin akan selalu berbeda dengan data aktual. Perbedaan antara nilai peramalan dengan data aktual disebut kesalahan peramalan (*error*). Meskipun suatu jumlah kesalahan peramalan tidak dapat dihindari, namun tujuan peramalan adalah agar kesalahan diminimalisir (Widjajati et al., 2017).

Metode peramalan yang memiliki nilai kesalahan hasil peramalan terkecil, akan dianggap sebagai metode yang cocok untuk digunakan. Terdapat banyak metode dalam perhitungan kesalahan peramalan, diantaranya yang akan digunakan dalam peramalan ini adalah *Mean Absolute Percentage Error* dan *Root Mean Squared Error*. Berikut adalah jenis-jenis cara menghitung nilai kesalahan :

Rata-rata Kesalahan Kuadrat (*Root Mean Squared Error*)

$$\text{RMSE} = \sqrt{\text{MSE}} = \sqrt{\sum_{t=1}^n \frac{e_t^2}{n}}, \quad (3.1)$$

Rata-rata Persentase Absolut (*Mean Absolute Percentage Error*)

$$\text{MAP E} = \sum_{t=1}^n \frac{|PE_t|}{n}, \quad (3.2)$$

keterangan :

$$PE_t : \text{kesalahan persentase} = \frac{(X_t - F_t)}{X_t} \times 100$$

E_t : kesalahan periode $t = X_t - F_t$

X_t : data aktual periode t

n : banyak periode t

t : tahun periode

H. Penelitian yang Relevan

Dalam penelitian ini yang berjudul “Peramalan Suhu Udara Maksimum dan Minimum Harian Menggunakan Metode ARIMA dan *Exponential Smoothing*”, ada beberapa penelitian yang relevan sebagai referensi dari penulis. Berikut merupakan persamaan dan penelitian ini dengan penelitian yang lainnya :

Tabel 1. Penelitian-penelitian yang Relevan

No	Judul	Persamaan	Perbedaan
1.	Peramalan Suhu Udara dan Dampaknya Terhadap Konsumsi Energi Listrik di Kalimantan Timur. (Jurnal Ilmu Matematika dan Terapan; Vol.14, No.3, 2020)	Penelitian yang akan dilakukan sama yaitu untuk meramalkan suhu udara dan menggunakan metode yang sama yaitu ARIMA	Penelitian yang akan dilakukan menggunakan dua metode, sedangkan penelitian tersebut hanya satu metode.
2.	Peramalan Suhu Udara Jangka Pendek di Kota Banda Aceh dengan Metode <i>Autoregressive Integrated Moving Average</i> (ARIMA) (Malikussaleh <i>Journal of Mechanical Science and Technology</i> ; Vol.5, No.1, 2017)	Penelitian yang akan dilakukan sama yaitu untuk meramalkan suhu udara dan menggunakan metode yang sama yaitu ARIMA.	Penelitian yang akan dilakukan menggunakan dua metode, sedangkan penelitian tersebut hanya satu metode.
3.	Prediksi Kecepatan Arus Laut Di Perairan Selat Bali Menggunakan Metode <i>Exponential Smoothing Holt-Winters</i> . (Math Vision; Vol.2, No.1, 2020)	Sama-sama menggunakan Metode <i>Exponential Smoothing</i> .	Perbedaan terdapat pada hal yang akan di teliti.
4.	Penerapan Metode <i>Winter S Exponential Smoothing</i> Dan <i>Single Moving Average</i> Dalam Sistem Informasi Pengadaan	Sama-sama menggunakan metode	Perbedaan terdapat pada hal yang akan di teliti.

	Obat Rumah Sakit. (Prosiding Seminar Nasional Manajemen Teknologi XI;Vol.12,No.1,2010)	<i>Exponential Smoothing.</i>	
5.	Perbandingan Peramalan Menggunakan Metode <i>Ekspensial Holt-Winters Smoothing</i> dan ARIMA. (<i>Unnes Journal of MaThematics</i> ;Vol.6,No.1,2017)	Metode yang digunakan sama seperti yang akan penulis lakukan.	Perbedaan terdapat pada hal yang akan di teliti.
6.	Penerapan Metode <i>Moving Average</i> dan <i>Exponential Smoothing</i> Pada Peramalan Produksi Industri Garment. (Jurnal Informatika;Vol.5,No.2,2018)	Sama-sama menggunakan metode <i>Exponential Smoothing.</i>	Perbedaan terdapat pada hal yang akan di teliti
7.	Peramalan Temperatur Rata-rata dan Kelembaban Rata-rata Harian Kabupaten Seram Bagian Timur Menggunakan ARIMA Box-Jenkins. (INFERENSI, Vol.20,No.10,2020)	Penelitian yang akan dilakukan sama yaitu untuk meramalkan suhu udara dan menggunakan metode yang sama yaitu ARIMA.	Penelitian yang akan dilakukan menggunakan dua metode, sedangkan penelitian tersebut hanya satu metode.
8.	Peramalan Curah Hujan Di Kota Ambon Menggunakan Metode <i>Holt-Winters Exponential Smoothing.</i> (Jurnal Ilmu Matematika dan Terapan;Vol.11,No.2,2017)	Sama-sama menggunakan metode <i>Exponential Smoothing.</i>	Perbedaan terdapat pada hal yang akan di teliti.
9.	Peramalan Temperatur Udara di Kota Surabaya dengan Menggunakan ARIMA dan <i>Artificial Neural Network.</i> (Jurnal Sains dan Seni ITS;Vol.1,No.1,2012)	Penelitian yang akan dilakukan sama yaitu untuk meramalkan suhu udara dan menggunakan metode yang sama yaitu ARIMA.	Penelitian yang akan dilakukan menggunakan dua metode, sedangkan penelitian tersebut hanya satu metode.
10	<i>A study of time series models ARIMA and ETS. (Modern Education and Computer Science</i> ; Vol.4,2017)	Metode yang digunakan sma yaitu ARIMA dan ETS.	Perbedaan terdapat pada hal yang akan di teliti.